



WVC 2017



Anais do XIII Workshop de Visão Computacional



Catálogo da Publicação na Fonte. UFRN / SISBI / Biblioteca Setorial
Especializada do Centro de Ciências Exatas e da Terra – CCET.

Workshop de Visão Computacional (13. : 2017 : Natal, RN).

XIII Workshop de Visão Computacional [recurso eletrônico]: anais do 13º
Workshop de Visão Computacional realizado na UFRN, Natal, Brasil em 2017 /
organização: Rafael Beserra Gomes, Luiz Marcos Garcia Gonçalves. – 1. ed. –
Natal: EDUFRN, 2018.

167 p. : PDF ; 100263 Kb.

Modo de acesso: <https://repositorio.ufrn.br>

ISBN 978-85-425-0775-1

1. Computação. 2. Visão computacional. 3. Processamento de imagens. 4.
Aprendizado de máquina - Aplicações. I. Gomes, Rafael Beserra. II. Gonçalves,
Luiz Marcos Garcia. III. Título.

RN/UF/BSE-CCET

CDU 004

Exploring fuzzy numbers for image texture analysis

Geovane da Silva Patrício, Carolina Yukari Veludo Watanabe
 Computer Science Departament
 Federal University of Rondônia
 e-mail: diouvane.gs@gmail.com, carolina@unir.br

Resumo—Fuzzy numbers present the ability to represent uncertainties, instead of conventional methods based on traditional logic (crisp). Digital images may suffer damage such as noise or distortion during the capture process, and the theory of fuzzy logic and sets becomes an interesting approach to address such problems. Aiming to explore this approach in the image texture analysis, in this work we study the method Location Fuzzy Pattern (LFP), proposed by Vieira (2013), which was originally developed using sigmoid (LFP-s), symmetric triangular (LFP-t) and gaussian (LFP-g) functions to calculate the membership degrees of the central pixel in relation to its neighborhood. Here, we extended the method to the symmetric trapezoidal function, which we called LFP-tr. We compared the performance of the four membership functions, using two image data sets: Brodatz, and one with lung pathologies. The best results were using the sigmoid function and we get high accuracy to characterize lung pathologies.

Index Terms — Feature Extraction, texture analysis, Fuzzy Numbers, Image Processing.

I. INTRODUÇÃO

Com o desenvolvimento de equipamentos de aquisição de imagens na área médica, o avanço do uso da internet e a popularização de smartphones, um grande volume de dados de imagens são gerados atualmente. Assim, diversas técnicas computacionais têm sido desenvolvidas para realizar o processamento automático dessas imagens visando dar suporte a sistemas de auxílio ao diagnóstico e sistemas de recuperação de imagens por conteúdo.

Uma imagem digital pode ser tratada como uma coleção de pixels representados como grandes matrizes de números inteiros correspondentes às intensidades ou cores destes pixels em diferentes posições na imagem. O objetivo geral de uma extração de característica é extrair padrões significativos a partir destes números. Estes padrões podem ser encontrados nas cores, texturas ou formas presentes em uma imagem digital. As medições geradas a partir destes padrões são denotadas como características de baixo nível (*low-level features*) [1].

Uma abordagem importante para a descrição de regiões de uma imagem é quantificar seu conteúdo de textura. A textura é uma das mais importantes características presentes em uma imagem. Enquanto a cor é usualmente a propriedade de um pixel, as texturas só podem ser medidas a partir de um conjunto de pixels. Devido ao seu grande poder discriminatório, as características presentes nas texturas são amplamente usadas em recuperação de imagens e técnicas semânticas de aprendizagem [2].

Um grande número de técnicas tem sido proposto para a extração de características de textura. Com base no domínio do qual o recurso da textura é extraído, estas podem ser amplamente classificadas por métodos de extração de características de textura espaciais (métodos estatísticos e estruturais) e espectrais [2].

Métodos estatísticos tendem a definir textura como suave, grossa, fina, granulada etc. Como descritores estatísticos simples podem ser citados a média, momentos, uniformidade, correlação, contraste, homogeneidade e entropia. Métodos estruturais lidam com a captura do arranjo espacial de primitivas de textura presentes na imagem. Já os métodos espectrais são baseados em propriedades do espectro de *Fourier* e são usadas para detectar a periodicidade global em uma imagem pela identificação de picos de alta energia no espectro [3] [1].

Características espaciais podem ser extraídas de qualquer tipo de formato sem perda de informação e geralmente possuem significado semântico compreensíveis por humanos. Contudo, é difícil adquirir um número suficiente de características espaciais para a representação de uma imagem ou região, e métodos espaciais são usualmente sensíveis a ruídos. Por outro lado, os métodos espectrais são robustos e utilizam menos recursos computacionais, visto que a convolução no domínio espacial é obtida como o produto no domínio da frequência, na qual é implementada usando as Transformadas Rápidas de *Fourier* (FFT), mas não possuem significado compreensível por humanos.

As abordagens por micropadrões locais surgem então como uma alternativa promissora para tratar regiões e extração de características de imagens digitais. Nesta abordagem, os descritores de textura local têm como objetivo modelar algoritmos que tenham a capacidade de analisar as propriedades da superfície de um objeto. O processo é realizado a partir da análise e da codificação de uma vizinhança, computando as relações de intensidades relativas entre os pixels desta vizinhança.

Com relação ao processo de captura/aquisição de imagens digitais, estas podem sofrer distorções, sejam borrões ou ruídos. Uma alternativa que tem se mostrado eficaz para representar ou manipular tais incertezas são os números fuzzy. Inicialmente, os sistemas fuzzy surgiram como uma forma de modelar e tratar incertezas inerentes a língua ou ao cotidiano humano.

Um método que utiliza o poder descritivo dos sistemas e números fuzzy para modelar a distribuição de níveis de cinza de um micropadrão como um conjunto fuzzy e que a partir

de funções de pertinência gera códigos fuzzy para representar o grau de pertinência dos pixels vizinhos em relação ao pixel central é o proposto por [4], chamado *Local Fuzzy Pattern* (LFP), para caracterização de textura. Originalmente, este método foi apresentado usando as funções sigmoide (LFP-s), triangular simétrica (LFP-t) e gaussiana (LFP-g) para calcular os graus de pertinência do pixel central.

Assim, o objetivo deste trabalho foi explorar o método desenvolvido por [4], estendendo-o para a função trapezoidal simétrica, o qual chamamos de LFP-tr, para caracterização de textura de imagens médicas. Para analisar o desempenho da LFP-tr e das outras funções, foram calculadas as taxas de acerto usando a distância Chi-quadrado, sobre duas bases de imagens: Brodatz e uma com patologias de pulmão. O restante do artigo está estruturado da seguinte maneira: na Seção II são apresentados os trabalhos correlatos ao LFP, na Seção III é apresentado o descritor proposto, chamado LFP-tr, e a metodologia de desenvolvimento da pesquisa, a Seção IV apresenta os resultados e discussões, comparando o desempenho do LFP-tr aos propostos na literatura (LFP-s, LFP-g e LFP-t), e por fim a Seção V apresenta as conclusões.

II. TRABALHOS CORRELATOS

O *Texture Unit* (TU) [5] foi um dos primeiros métodos propostos para caracterização e classificação de textura, onde se relaciona a intensidade dos níveis de cinza de uma vizinhança. A principal desvantagem deste descritor é a quantidade elevada de códigos gerados, há 6561 unidades de textura possíveis.

Já o *Local Binary Pattern* (LBP) [6], outro método utilizado na descrição e classificação de texturas, reduz a quantidade de códigos gerados pelo TU para 256. No entanto, com esta simplificação, há uma redução do poder discriminatório e o aumento da sensibilidade a ruídos, visto que é realizada uma comparação *crisp* entre os pixels, perdendo assim, a informação relacionada com a quantidade real da diferença entre os valores dos pixels.

Algumas metodologias que utilizam o poder descritivo dos conjuntos e números *fuzzy* já foram propostas, como: segmentação de imagens de textura [7] [8]; análise, reconhecimento e classificação [9], [10]. Os problemas citados acima obtiveram a ajuda da lógica *fuzzy* para gerenciar adequadamente informações vagas ou ambíguas, tornando o processo de caracterização e classificação mais flexível. Todas, de uma certa forma, são versões fuzzificadas da metodologia *Local Binary Pattern* (LBP) [6].

Em [4] é proposta uma generalização do LBP para usar números fuzzy, chamado *Local Fuzzy Pattern* (LFP), o qual foi estudado e explorado neste trabalho para caracterização de texturas da base amplamente conhecida de Brodatz e uma base de imagens de pulmão para diferenciação de patologias.

III. METODOLOGIA

Nesta seção, a metodologia proposta usando *Local Fuzzy Pattern - trapezoidal pertinence function* (LFP-tr) é descrita. O método LFP-tr aqui proposto é uma extensão do método LFP desenvolvida por [4], que originalmente utilizou as funções

de pertinência sigmoide (LFP-s), triangular simétrica (LFP-t) e gaussiana (LFP-g).

Na Fig. 1 está representado o pipeline da metodologia realizada neste trabalho, e cada uma das etapas estão descritas a seguir.

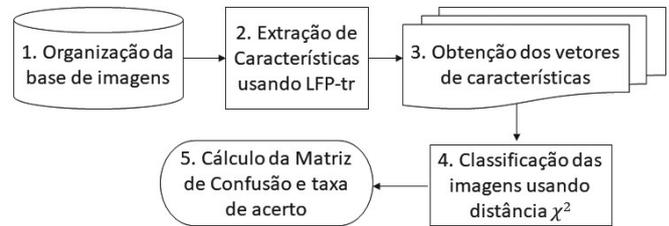


Figura 1: Metodologia

A. Organização da base de imagens

Nesta seção estão descritas as bases de imagens utilizadas.

1) *Álbum de Brodatz*: A primeira base de imagens de texturas utilizada para avaliar o desempenho do extrator de características aqui proposto com relação aos originalmente propostos por [4], foi o álbum de Brodatz [11]. Este conjunto de imagens digitalizadas possui uma enorme variedade de texturas e é amplamente utilizado para testes e pesquisas na área de processamento de imagens digitais visando a extração de características.

Foram selecionadas do álbum de Brodatz 111 imagens de texturas naturais e sintéticas. Cada imagem é considerada como uma classe de dimensão 640×640 pixels. De cada classe são extraídas 10 amostras aleatórias, como exemplificado na Fig. 2, totalizando assim em 1110 amostras de texturas. Foram geradas amostras de diversos tamanhos: 45×45 , 50×50 , 55×55 , 60×60 , 65×65 , 70×70 , 75×75 , 80×80 , 85×85 e 90×90 .

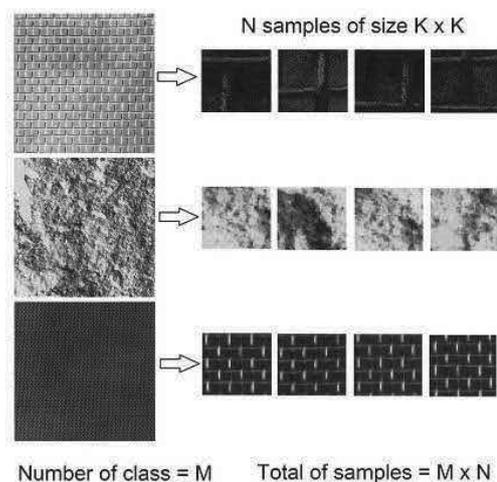


Figura 2: Geração de amostras a partir das imagens de textura do álbum de Brodatz.

2) *Álbum de Pulmão*: Para verificar a aplicação do vetor de característica proposto no domínio de imagens médicas, a segunda base de imagens utilizada pertence a um conjunto

de imagens de tomografia computadorizada de alta resolução de exames torácicos focados em pulmão [12]. A base de imagens está dividida em um total de seis classes distintas, de acordo com a patologia detectada: enfisema, consolidação, vidro fosco, favo de mel (ou faveolamento), espessamento e normal. Na Fig. 3 uma amostra de cada classe citada anteriormente é exemplificada.

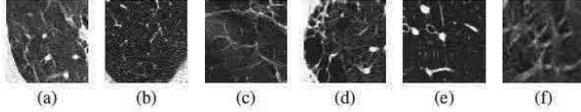


Figura 3: Exemplos de texturas presentes no álbum de Pulmão (a) enfisema (b) consolidação (c) espessamento (d) faveolamento (e) normal (f) vidro fosco [12].

Cada classe de imagens possui 451 amostras distintas, totalizando assim em 2706 imagens utilizadas no processo de classificação e extração de características. Diferentemente da base de imagens de Brodatz, as amostras possuem um tamanho fixo de 64×64 pixels.

B. Método Local Fuzzy Pattern usando função trapezoidal - LFP-tr para extração de características de textura

A abordagem utilizada neste trabalho chama-se *Local Fuzzy Pattern* (LFP), proposta inicialmente por [4], que apesar de receber a mesma nomenclatura do método proposto por Caponetti et al. (2006), se diferencia pelo fato de uma função de pertinência estar diretamente responsável pelo código LFP.

Tal metodologia é baseada na teoria *fuzzy*, porém sem o uso de regras *fuzzy*. Os pixels são interpretados como números *fuzzy* e a vizinhança como um conjunto *fuzzy*.

Tratando os níveis de cinza de um pixel como números *fuzzy* é possível incorporar a sua variabilidade inerente aos conceitos *fuzzy*, fornecendo assim uma metodologia mais apropriada para tratar imagens digitais. O fato de a abordagem utilizada se basear em números *fuzzy* ao invés de conjuntos *fuzzy* implica diretamente no custo computacional da metodologia.

A representação por números *fuzzy* é paramétrica e a definição de uma função de pertinência apropriada é heurística e aberta a diversas possibilidades. A definição das funções de pertinência baseia-se nas propriedades da vizinhança do micropadrão $W \times W$ e do pixel central $g(i, j)$ em uma imagem digital. Cada distribuição de níveis de cinza dentro da vizinhança é considerada um conjunto *fuzzy* devido ao grau de incerteza gerado pelos processos de aquisição ou ruídos imprevisíveis que podem afetar uma imagem [4].

O grau de pertinência do pixel central $g(i, j)$ para o micropadrão definido pela vizinhança $W \times W$ é apresentado na Eq. 1:

$$\hat{\mu}_{g(i,j)} = \frac{\sum_{k=1}^W \sum_{l=1}^W [f_{g(i,j)} P(k,l)]}{\sum_{k=1}^W \sum_{l=1}^W P(k,l)} \quad (1)$$

onde $f_{g(i,j)}$ é a função de pertinência que irá gerar os valores das pertinências em relação ao pixel central, e $P(k, l)$ é a matriz de pesos para a vizinhança $A(k, l)$ com a mesma dimensão $W \times W$.

O grau de pertinência $\hat{\mu}_{g(i,j)}$ do pixel central definido pela vizinhança $W \times W$ é dado pela média ponderada dos valores de pertinências de cada pixel. Tal grau de pertinência define o código LFP que reflete a estrutura do micropadrão dentro da vizinhança considerada.

Neste trabalho propomos a extensão da metodologia de [4] para a função de pertinência trapezoidal simétrica, ao que chamamos de *Local Fuzzy Pattern - Trapezoidal* (LFP-tr), que possui um aspecto semelhante a função de pertinência triangular simétrica. Para analisar matematicamente a função trapezoidal, a representação matemática e gráfica do número *fuzzy* trapezoidal é apresentada na Eq. 2 e na Fig. 4, respectivamente:

$$\varphi_A(x) = \begin{cases} \frac{x-a}{m-a}, & \text{se } a \leq x < m \\ 1, & \text{se } m \leq x \leq n \\ \frac{b-x}{b-n}, & \text{se } n < x \leq b \\ 0, & \text{caso contrário} \end{cases} \quad (2)$$

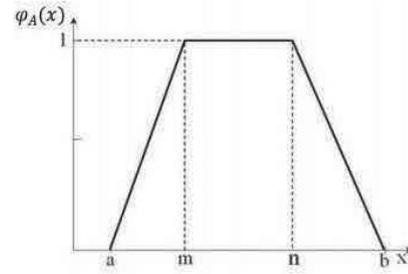


Figura 4: Representação gráfica da função de pertinência trapezoidal [4].

Partindo do fato de que se trata de um trapézio simétrico, ou seja, $m - a = n - m = b - n = \delta$, e colocando todos os valores em função de m , temos:

$$a = m - \delta; n = m + \delta; b = m + 2\delta \quad (3)$$

sendo δ o espalhamento do número *fuzzy*.

Realizando as substituições em (2), obtemos:

$$v1 = \frac{x-a}{m-a} = \frac{x-(m-\delta)}{m-(m-\delta)} = 1 + \frac{x-m}{\delta} \quad (4)$$

$$v2 = \frac{b-x}{b-n} = \frac{(m+2\delta)-x}{(m+2\delta)-(m+\delta)} = 2 - \frac{x-m}{\delta} \quad (5)$$

Considerando que os valores da função de pertinência podem assumir os valores $[0, 1]$, uma função trapezoidal simétrica pode então ser definida como:

$$f_{g(i,j)} = \max(\min(\min(v1, v2), 1), 0). \quad (6)$$

Substituindo os valores de $v1$ e $v2$, temos:

$$f_{g(i,j)} = \max\left(\min\left(\min\left(1 + \frac{x-m}{\delta}, 2 - \frac{x-m}{\delta}\right), 1\right), 0\right) \quad (7)$$

onde x e m representam a vizinhança analisada $A(k, l)$ e o pixel central $g(i, j)$, respectivamente.

A função de pertinência trapezoidal gera valores no intervalo $[0, 1]$, sendo necessária a conversão para um esquema de nível de cinza de 8 bits, os graus de pertinência são multiplicados por 255 e arredondados ao fim. O histograma do LFP-tr, assim como as demais funções analisadas, possuem 256 *bins* (quantidade de valores representados no histograma e que variam entre 0 e 255).

As matrizes de peso de tamanho 3×3 e 5×5 possuem a seguinte forma:

$$P(k, l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (8)$$

$$P(k, l) = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (9)$$

C. Obtenção dos vetores de características

O conjunto de amostras extraídas da base de imagens de texturas de Brodatz foi submetida ao extrator de características *Local Fuzzy Pattern* (LFP) [4], utilizando as funções de pertinência sigmoideal (LFP-s), triangular (LFP-t), gaussiana (LFP-g), todas estas já utilizadas no trabalho referenciado, acrescentando-se a função de pertinência trapezoidal (LFP-tr), para posterior comparação de resultados.

Para as bases de imagens de textura, com diferentes tamanhos de amostras, foram aplicados os métodos LFP-s, LFP-t, LFP-g e LFP-tr, gerando seus histogramas a partir das distribuições de probabilidade dos códigos provenientes dos descritores utilizados. Cada imagem passa então a ser representada por um vetor de características com 256 atributos.

D. Classificação das amostras

Após a extração das características das imagens e da obtenção dos vetores de características, estes últimos são classificados usando a distância Chi-quadrado [4], conforme Eq. 10:

$$\chi^2(P_i, Q_i) = \frac{1}{2} \sum_{i=0}^{255} \frac{(P_i - Q_i)^2}{(P_i + Q_i)} \quad (10)$$

onde Q_i é a frequência do nível de cinza da amostra avaliada e P_i a frequência do nível de cinza da amostra do conjunto que está sendo comparada com a amostra avaliada. Para cada histograma de uma amostra gerado, a validação cruzada *leave-one-out* (forma particular de validação cruzada onde o número de classificação é o número de exemplos, o classificador é construído n vezes, utilizando os dados completamente no treino e sendo custoso computacionalmente) é utilizada para comparação com os histogramas das demais amostras (1109 outras amostras para o álbum de Brodatz), por exemplo.

Uma classificação é considerada correta se esta pertencer à mesma classe da amostra para qual a menor distância foi encontrada. Os resultados são armazenados em uma matriz de confusão (o número de acertos, para cada classe, se localiza na diagonal principal $M(C_i, C_j)$, os demais elementos, $M(C_i, C_j)$, para $i \neq j$, representam erros de classificação) e a sensibilidade (resultados de classificação verdadeiros positivos) é então calculada de acordo com a Eq. 11.

$$S = \frac{TP}{TP + FN} \quad (11)$$

onde TP são os verdadeiros positivos e FN os falsos negativos.

IV. RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados experimentais obtidos com o descritor LFP-tr comparado aos propostos por [4] (LFP-s, LFP-t e LFP-g). As bases de imagens utilizadas foram o álbum de Brodatz e o conjunto de amostras de exames computadorizados com foco em pulmão, apresentados anteriormente.

Pelo fato de o método utilizado ser paramétrico e a escolha das funções ideais ser heurística, é necessário definir os parâmetros utilizados em cada descritor. Na função sigmoideal há a inclinação da curva representada por β , as funções triangular e trapezoidal têm em comum o parâmetro δ que define o espalhamento dos números *fuzzy*, e σ definindo o desvio padrão na função gaussiana. A seguir são apresentados os resultados e os parâmetros que propiciaram os melhores resultados para todos os descritores.

A. Resultados para o álbum de Brodatz

As Tabelas I e II apresentam as sensibilidades obtidas para a vizinhança de tamanho 3×3 , enquanto as Tabelas III e IV mostram os valores dos parâmetros utilizados. Os valores em negrito representam o melhor valor de sensibilidade obtido de acordo com o tamanho de amostra e seu correspondente descritor.

Tabela I: Melhores valores de sensibilidade obtidos pelas funções analisadas utilizando uma vizinhança 3×3 .

3x3	45x45	50x50	55x55	60x60	65x65
LFP-s	81,622	86,306	90	91,802	92,973
LFP-t	71,802	78,018	79,459	82,883	86,667
LFP-g	77,297	82,432	83,964	86,847	88,829
LFP-tr	72,252	74,685	80,541	84,144	85,766

Tabela II: Demais tamanhos de amostras analisadas utilizando a vizinhança 3×3 e os valores de sensibilidade obtidas.

3x3	70x70	75x75	80x80	85x85	90x90
LFP-s	94,414	96,667	96,216	96,667	97,207
LFP-t	88,198	89,189	91,532	92,162	93,333
LFP-g	91,892	92,342	93,604	94,865	95,586
LFP-tr	89,099	90,541	90,541	91,532	93,243

Comparando os resultados fica evidente que o aumento no tamanho das amostras proporciona uma melhor classificação das imagens. A função de pertinência sigmoideal (LFP-s)

Tabela III: Parâmetros utilizados para obter os melhores valores de sensibilidade utilizando uma vizinhança 3x3.

	3x3	45x45	50x50	55x55	60x60	65x65
β (LFP-s)	1,002	0,75	0,95	1,05	0,9	
δ (LFP-t)	5,6	5,6	5,8	5,65	5,65	
σ (LFP-g)	1,8	1,8	1,8	1,55	1,65	
δ (LFP-tr)	5,6	5,8	5,4	5,4	5,6	

Tabela IV: Valores de parâmetros e seus respectivos tamanhos de amostra.

	3x3	70x70	75x75	80x80	85x85	90x90
β (LFP-s)	0,71	0,75	0,75	0,725	1,005	
δ (LFP-t)	5,65	5,6	5,8	5,72	5,72	
σ (LFP-g)	1,8	1,8	1,8	1,8	1,8	
δ (LFP-tr)	5,4	5,8	5,3	5,3	5,8	

obteve os melhores valores de sensibilidade dentre todos os tamanhos de amostras comparados, chegando a superar em mais de 6% o segundo melhor valor de sensibilidade, no caso da amostra de tamanho 75x75 do álbum de Brodatz. Observa-se que a função trapezoidal mostrou-se mais eficiente que a função triangular em alguns tamanhos de amostras.

As Tabelas V e VI apresentam os valores de sensibilidade obtidos para a vizinhança de tamanho 5x5:

Tabela V: Melhores valores de sensibilidade obtidos pelas funções analisadas utilizando uma vizinhança 5x5.

	5x5	45x45	50x50	55x55	60x60	65x65
LFP-s	66,036	72,432	76,757	81,892	85,225	
LFP-t	60,541	67,207	71,892	75,225	79,369	
LFP-g	68,649	73,874	77,568	79,73	85,315	
LFP-tr	60,27	66,396	72,883	77,207	80,541	

Tabela VI: Demais tamanhos de amostras analisadas utilizando a vizinhança 5x5 e os valores de sensibilidade obtidas.

	5x5	70x70	75x75	80x80	85x85	90x90
LFP-s	88,018	89,73	92,523	93,694	95,045	
LFP-t	81,441	85,856	86,937	88,468	89,82	
LFP-g	86,216	88,378	91,351	92,072	92,523	
LFP-tr	84,234	85,946	87,387	89,189	90,721	

Os valores de sensibilidade obtidos mostram que um aumento da vizinhança (de 3x3 para 5x5) não necessariamente proporcionou um melhor processo classificatório. Tanto usando uma vizinhança 3x3 quanto uma de 5x5, para todos os descritores a sensibilidade aumentou de acordo com o aumento do tamanho da amostra. Isso ocorreu porque é possível coletar um maior número de informações da textura.

Ainda é possível notar que, a partir de amostras de tamanho 60x60, o descritor LFP-s (sigmoide) foi o que apresentou melhores valores de sensibilidade. Apesar de na maior parte dos resultados do descritor proposto LFP-tr (trapezoidal) ter obtido um desempenho um pouco melhor que o LFP-t (triangular), e em alguns momentos um desempenho um pouco inferior, pode-se observar que ambos apresentaram um desempenho muito semelhante, inclusive, quando observados os parâmetros encontrados para os melhores valores de sensibilidade, que na maioria das vezes possuíam o mesmo valor de δ .

Tabela VII: Parâmetros utilizados para obter os melhores valores de sensibilidade utilizando uma vizinhança 5x5.

	5x5	45x45	50x50	55x55	60x60	65x65
β (LFP-s)	0,9	0,9	0,9	0,9	0,9	0,9
δ (LFP-t)	5,8	5,8	5,8	5,8	5,7	5,8
σ (LFP-g)	1,1	1,1	1,1	1,1	1,1	1,1
δ (LFP-tr)	5,8	5,8	5,8	5,8	5,4	5,8

Tabela VIII: Demais valores de parâmetros e seus respectivos tamanhos de amostra.

	5x5	70x70	75x75	80x80	85x85	90x90
β (LFP-s)	0,9	0,9	0,9	0,9	0,9	0,95
δ (LFP-t)	5,72	5,8	5,8	5,8	5,8	5,8
σ (LFP-g)	1,15	1,1	1,1	1,1	1,1	1,1
δ (LFP-tr)	5,35	5,3	5,35	5,65	5,8	

B. Resultados para o álbum de pulmão

A base de imagens de pulmão se divide em seis classes distintas, cada classe representando um tipo diferente de laudo médico, os possíveis laudos são: 1 - enfisema; 2 - consolidação; 3 - espessamento; 4 - faveolamento; 5 - normal; 6 - vidro fosco. Para cada classe de imagens foram selecionadas 451 amostras de tamanho único de 64x64 pixels, num total de 2706 amostras. Aplicando os descritores LFP-s, LFP-t, LFP-g e LFP-tr, os valores de sensibilidade foram obtidos e apresentados nas Tabelas IX e X seguidos dos valores de parâmetros utilizados.

Tabela IX: Valores de sensibilidade obtidos para vizinhança 3x3.

	3x3	64x64
LFP-s		80,377
LFP-t		65,965
LFP-g		66,408
LFP-tr		64,339

Na Tabela IX é possível notar que o melhor valor de sensibilidade foi obtido pelo descritor LFP-s (sigmoide), em negrito. O descritor LFP-tr (trapezoidal) obteve o valor de sensibilidade mais baixo, considerando uma vizinhança 3x3.

Tabela X: Parâmetros utilizados para obter os melhores valores de sensibilidade para cada descritor, com uma vizinhança 3x3.

	3x3	64x64
β (LFP-s)		1,2
δ (LFP-t)		70
σ (LFP-g)		20
δ (LFP-tr)		49

Já as Tabelas XI e XII definem os valores para uma vizinhança 5x5 obtidos com o álbum de pulmão. É possível observar que o melhor valor de sensibilidade obtido foi pelo descritor LFP-s, sendo o LFP-tr o segundo melhor resultado. O descritor que apresentou o desempenho mais baixo foi o LFP-g, ao contrário do álbum de Brodatz, que este descritor apresentou o segundo melhor desempenho na maioria dos experimentos realizados. Na tabela dos parâmetros, diferentemente dos parâmetros encontrados para o álbum Brodatz, é possível ver que os valores de δ encontrados para a função triangular foi bem diferente da trapezoidal.

Tabela XI: Valores de sensibilidade para vizinhança 5×5 .

5x5	64x64
LFP-s	74,759
LFP-t	63,895
LFP-g	63,303
LFP-tr	64,929

Tabela XII: Parâmetros utilizados para obter os melhores valores de sensibilidade, com uma vizinhança 5×5 .

5x5	64x64
LFP-s	7
LFP-t	52,5
LFP-g	20
LFP-tr	27,5

V. CONCLUSÃO

Este artigo apresentou um novo descritor, chamado LFP-tr, que é uma extensão da função LFP proposta por [4], para a função de pertinência trapezoidal. Para validar o desempenho deste descritor, foram realizados experimentos em duas bases de imagens, e os valores de sensibilidade de todas as funções de pertinência, quando aplicados sobre a base de imagem de Brodatz, foram muito satisfatórios, sendo superiores a 90% em tamanhos de amostras maiores. Observa-se pelos resultados que o descritor proposto obteve desempenho muito semelhante ao LFP-t. Também foi possível verificar que o descritor LFP-s mostrou-se mais adequado para a maioria das amostras, e que tanto o LFP-tr quanto o LFP-t e o LFP-g variaram no *ranking* de desempenho. Analisando o desempenho do LFP para todas as funções de pertinência, é possível observar que o método não se comporta bem para amostras pequenas, com tamanho inferior a 60×60 , e que o uso de uma vizinha menor (no caso a de 3×3) permitiu que características de textura mais significativas fossem extraídas. Assim, ressalta-se a premissa de que a escolha do tipo de extrator, do tipo de função e dos parâmetros utilizados muda de acordo com a base de imagens analisadas.

Os valores obtidos de sensibilidade com a base de pulmão para o LFP-tr foram consideravelmente inferiores aos obtidos com o álbum de Brodatz para um tamanho de amostra semelhante, mas o descritor LFP-s apresentou uma sensibilidade

acima de 80%, o que pode ser considerado um resultado promissor, já que o problema de identificação de patologias em pulmão é de difícil caracterização.

Assim, o LFP mostra-se sensível à função de pertinência utilizada e também aos parâmetros para definição dessas funções. O maior poder discriminatório dos conjuntos e números fuzzy mostrou ser uma boa forma de analisar, reconhecer e classificar micropadrões presentes em imagens digitais e na aplicação médica.

REFERÊNCIAS

- [1] J. Ahmad, M. Sajjad, I. Mehmood, S. Rho, and S. W. Baik, "Describing colors, textures and shapes for content based image retrieval-a survey," *arXiv preprint arXiv:1502.07041*, p. 15, 2015.
- [2] D. Zhang, M. M. Islam, and G. Lu, "A review on automatic image annotation techniques," *Pattern Recognition*, vol. 45, no. 1, pp. 346–362, 2012.
- [3] R. C. Gonzalez and R. E. Woods, *Processamento de imagens digitais*, terceira ed. Edgard Blucher, 2008.
- [4] R. T. Vieira, "Análise de micropadrões em imagens digitais baseada em números fuzzy," Msc. Dissertation, 2013.
- [5] D.-C. He and L. Wang, "Texture unit, texture spectrum, and texture analysis," *IEEE transactions on Geoscience and Remote Sensing*, vol. 28, no. 4, pp. 509–512, 1990.
- [6] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern recognition*, vol. 29, no. 1, pp. 51–59, 1996.
- [7] L. Caponetti, C. Castiello, A. M. Fanelli, and P. Górecki, "Texture segmentation with local fuzzy patterns and neuro-fuzzy decision support," in *International Conference on Knowledge-Based and Intelligent Information and Engineering Systems*. Springer, pp. 340–347.
- [8] L. Tlig, M. Sayadi, and F. Fnaiech, "A new descriptor for textured image segmentation based on fuzzy type-2 clustering approach," *International Journal of Signal and Imaging Systems Engineering*, vol. 7, no. 3, pp. 159–166, 2014.
- [9] D. K. Iakovidis, E. G. Keramidis, and D. Maroulis, "Fusion of fuzzy statistical distributions for classification of thyroid ultrasound patterns," *Artificial Intelligence in Medicine*, vol. 50, no. 1, pp. 33–41, 2010.
- [10] S. Katsigiannis, E. Keramidis, and D. Maroulis, *FLBP: Fuzzy Local Binary Patterns*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014, pp. 149–175.
- [11] P. Brodatz, *Textures: a photographic album for artists and designers*. Dover Pubns, 1966.
- [12] M. P. da Silva, "Processamento de consultas por similaridade em imagens médicas visando à recuperação perceptual guiada pelo usuário," Ph.D. dissertation, 2009.